

*Aprendizado em RNAs do
tipo MLP – Multi Layer
Percetron – através do
algoritmo Error Back
Propagation*

© Prof. Emilio Del Moral – EPUSP

*Como escolhemos
os valores dos
diversos w 's ?*

© Prof. Emilio Del Moral Hernandez

O que devemos mirar quando exploramos o espaço de pesos W buscando que a RNA seja um bom modelo?

Devemos mirar Maximização da aderência = Mínimo E_{qm} possível

As Setas Verdes Indicam Situações que Devem ser Procuradas




10

© Prof. Emilio Del Moral – EPUSP

O que devemos buscar quando exploramos o espaço de pesos W buscando que a RNA seja um bom modelo?

Devemos buscar Maximização da aderência = Mínimo E_{qm} possível


As Setas Verdes Indicam Situações que Devem ser Procuradas



11

Conjunto de treino em arquiteturas supervisionadas (ex. clássico: MLP com Error Back Propagation)

12



A computação desejada da rede pode ser definida simplesmente através de amostras / exemplos do comportamento requerido

$$Eqm = \frac{1}{M} \sum_{\mu=1}^M (y_{rede}(\vec{X}^\mu, \vec{W}) - y^\mu)^2$$


$$\Delta \vec{W} = -\eta \cdot \vec{\nabla} Eqm$$

... em loop ...

Aprendizado: Espaço de pesos W é explorado visando aproximar ao máximo a computação da rede da computação desejada


© Prof. Emilio Del Moral Hernandez

12



Deduzindo as Equações do Aprendizado em RNAs do tipo MLP – Multi Layer Percetron – com o algoritmo Error Back Propagation (Gradiente Descendente)

© Prof. Emilio Del Moral – EPUSP



Enunciado c/ ligeira modificação em aula (para o seu melhor aprendizado)


Tarefa para desenvolvimento próprio e entrega até a aula de 4ª f. da Semana Santa +1(dia 4/abril)

- No grafo detalhado de uma rede 3-3-1 como o da aula, identifique o peso sináptico " w_{meu} " da primeira camada definido pelo último dígito do seu NUSP como segue:
- Último dígito 1: w_{1A} ; 2: w_{1B} ; 3: w_{1C} ; 4: w_{2A} ; 5: w_{2B} ; 6: w_{2C} ; 7: w_{3A} ; 8: w_{3B} ; 9: w_{3C} ; 0: w_{1A}
- Assumindo 100 exemplares de treino ($M=100$), identifique o exemplar de treino " μ_{meu} " associado ao 2º e 3º dígitos de seu NUSP como segue:
- Se 2º e 3º dígitos são 0 e 1, $\mu = 01$, se 2º e 3º dígitos são 0 e 2, $\mu = 02$, se 2º e 3º são 0 e 3, $\mu = 03$... se 4 e 1, $\mu = 41$... e assim por diante
- a) Fixando a entrada X da rede no exemplar empírico μ , ou seja $X = X^{\mu}$ e usando como alvo (target) empírico $y = y^{\mu}$, e visando o cálculo do gradiente do erro quadrático, necessário ao algoritmo de gradiente descendente (EBP – error back propagation), deduza com detalhe a expressão analítica da derivada parcial do erro quadrático do "seu" exemplar μ_{meu} com relação ao "seu" peso sináptico w_{meu} , ou seja, calcule $(\partial \text{Eq}^{\mu_{\text{meu}}} / \partial w_{\text{meu}})$; revise seus conceitos de derivada parcial e use a regra da cadeia na sua dedução.
- b) Agora empregue a formula analítica obtida em a) para um $(X^{\mu_{\text{meu}}}, y^{\mu_{\text{meu}}})$ empírico com valores razoáveis ao seu sistema regressor (já criado por você nas atividades de aula): defina valores numéricos e unidades das 4 grandezas envolvidas no cálculo, x_1^{μ} , x_2^{μ} , x_3^{μ} , e y^{μ} , e chegue ao valor numérico de $(\partial \text{Eq}^{\mu_{\text{meu}}} / \partial w_{\text{meu}})$
- c) Especifique o que teve que assumir em a e b (por não definido no enunciado).

© Prof. Emilio Del Moral Hernandez

18

O treinamento mira minimizar o Eqm das amostras ($X ; y$) de treino. (exclusivamente!)



21

© Prof. Emilio Del Moral – EPUSP

Um Exemplo Ilustrativo para o Conceito de Conjunto de Treinamento e dos M pares (X,y) ...

22

© Prof. Emilio Del Moral – EPUSP

Exemplo de regressão multivariada para estimação contínua usando MLP

- O valor do y contínuo ... neste exemplo corresponde ao volume de consumo futuro num dado tipo de produto “A” a ser ofertado pela empresa a um cliente corrente já consumidor de outros produtos da empresa (“B” e “C”), volume esse previsto com base em várias medidas quantitativas que caracterizam tal indivíduo. ... Assim, $y = \text{Consumo do Produto A} = F(x_1, x_2, x_3, x_4, x_5)$.
- Consideremos 4 variáveis de entrada no modelo preditivo neural, ou seja, temos 5 medidas em X :
 - x_1 : Idade do indivíduo
 - x_2 : Renda mensal do indivíduo
 - x_3 : Volume de clicks do indivíduo no website de exibição de produtos oferecidos pela empresa
 - x_4 : Volume de consumo desse cliente observado para outro Produto B da mesma empresa
 - x_5 : Volume de consumo desse cliente Produto C da mesma empresa
- Problema: desenvolver uma MLP para regressão contínua multivariada que permita estimar esse volume de consumo futuro y com base no conhecimento dos X e numa base de dados de aprendizado com esses dados X e y para 350 já clientes de universo populacional similar ao do novo consumidor potencial.

23

© Prof. Emilio Del Moral – EPUSP

Exemplo de dados empíricos tabulados em Excel ...

Cliente (μ)	Idade (x_1)	Renda (x_2)	Clics (x_3)	Consumo do Produto B (x_4)	Consumo do Produto C (x_5)	Consumo do Produto A (y)
1	50	78	302	958	136	9800
2	65	128	186	985	196	8760
3	57	150	221	1093	35	520
....						
M-2	16	19	51	707	131	11640
M-1	30	75	7	29	78	9640
M	19	47	116	285	124	5320

24

© Prof. Emilio Del Moral – EPUSP

Equivalente em .txt, em formato apropriado para o ambiente Multiple Back Propagation ...

Cliente (μ)	Idade (x_1)	Renda (x_2)	Clics (x_3)	Consumo do Produto B (x_4)	Consumo do Produto C (x_5)	Consumo do Produto A (y)
1	50	78	302	958	136	9800
2	65	128	186	985	196	8760
3	57	150	221	1093	35	520
....						
M-2	16	19	51	707	131	11640
M-1	30	75	7	29	78	9640
M	19	47	116	285	124	5320

Equivalente em txt
Para uso do MBP

Arquivo Editar Formatar Exibir Ajuda

```

Idade Renda Clics ConsumoA ConsumoB ConsumoA
50 78 302 958 136 9800
65 128 186 985 196 8760
57 150 221 1093 35 520
(...)
16 19 51 707 131 11640
30 75 7 29 78 9640
19 47 116 285 124 5320
  
```

75

Moral – EPUSP

*A estratégia de Aprendizado para o MLP
mais conhecida:*

Error Back Propagation (EBP)

= Propagação Reversa de Erro

*= Método do Gradiente personalizado
ao $E_{qm}(W)$ do MLP*

30

© Prof. Emilio Del Moral – EPUSP

*Mas entendamos PRIMEIRO
o que é o método numérico do
gradiente ascendente /
gradiente descendente
genérico,
que pode ser aplicado tanto para se
chegar paulatinamente ao máximo de
uma função quanto para se chegar ao
mínimo de uma função
(ascendente / descendente)*

31

© Prof. Emilio Del Moral – EPUSP

Chamada oral sobre a lição de casa: estudar / reestudar os conceitos e a parte operacional de derivadas parciais, do vetor Gradiente, e da regra da cadeia ...

- Derivadas parciais (que são as componentes do gradiente):

$$\partial f(a,b,c)/\partial a \quad \partial f(a,b,c)/\partial b \quad \partial f(a,b,c)/\partial c$$

- Vetor Gradiente, útil ao método do máximo declive:

$$(\partial \text{Eqm}(W)/\partial w_1, \partial \text{Eqm}(W)/\partial w_2, \partial \text{Eqm}(W)/\partial w_3, \dots)$$


$$\vec{\Delta W} = -\eta \cdot \vec{\nabla} \text{Eqm}_-$$

- Regra da cadeia, necessária ao cálculo de derivadas quando há encadeamento de funções:

$$\partial f(g(h(a))) / \partial a = \partial f / \partial g \cdot \partial g / \partial h \cdot \partial h / \partial a$$

© Prof. Emilio Del Moral – EPUSP


Derivada parcial- ilustração p/ função de 2 variáveis apenas



A visual model of the partial derivative

© Prof. Emilio Del Moral – EPUSP

Derivada parcial- ilustração p/ função de 2 variáveis apenas




A visual model of the partial derivative

34

© Prof. Emilio Del Moral – EPUSP

mais ilustrações p/ a derivada parcial em função de 2 variáveis




A visual model of the partial derivative with respect to y.

35

© Prof. Emilio Del Moral – EPUSP

Formação do vetor gradiente a partir de duas derivadas parciais




A visual model of the partial derivative

36

© Prof. Emilio Del Moral – EPUSP

<http://en.wikipedia.org/wiki/Gradient>

... O vetor gradiente indica a direção ascendente e seu módulo a magnitude de crescimento da função escalar – ilustração p/ função de 2 variáveis apenas



37

© Prof. Emilio Del Moral – EPUSP

Aprendizado do MLP por Error Back Propagation ...

$$\vec{\Delta W} = -\eta \cdot \vec{\nabla} E_{qm_}$$

Gradiente de Eqm no espaço de pesos = $(\partial E_{qm}(W)/\partial w_1, \partial E_{qm}(W)/\partial w_2, \partial E_{qm}(W)/\partial w_3, \dots)$

Chegando às fórmulas das derivadas parciais, necessárias à Bússola do Gradiente

38

© Prof. Emilio Del Moral – EPUSP


Processo de refinamentos graduais a cada iteração ...

W#0	Eqm#0	GradEqm(W#0)	DeltaW#0 = - n.GradEqm(W#0)
W#1 (= W#0 + DeltaW#0)	Eqm#1 (< Eqm#0)	GradEqm(W#1)	DeltaW#1 = - n.GradEqm(W#1)
W#2 (= W#1 + DeltaW#1)	Eqm#2 (< Eqm#1)	GradEqm(W#2)	DeltaW#2 = - n.GradEqm(W#2)
W#3 (= W#2 + DeltaW#2)	Eqm#3 (< Eqm#2)	GradEqm(W#3)	DeltaW#3 = - n.GradEqm(W#3)
W#4 (= W#3 + DeltaW#3)	Eqm#4 (< Eqm#3)	GradEqm(W#4)	DeltaW#4 = - n.GradEqm(W#4)
...	...	...	...
W#k (= W#k-1 + DeltaW#k-1)	Eqm#k (< Eqm#k-1)	GradEqm(W#k)	DeltaW#k = - n.GradEqm(W#k)
...	...	...	...

39

© Prof. Emilio Del Moral – EPUSP

A estratégia do EBP / Gradiente Descendente no aprendizado do MLP



40


© Prof. Emilio Del Moral – EPUSP

Este gráfico é denso e toca em muitos aspectos interrelacionados ... revisitemos alguns desses aspectos isoladamente com focos específicos nessas revisitas, assim teremos gráficos algo mais simples de interpretar ...

42

© Prof. Emilio Del Moral – EPUSP


A estratégia do EBP / Gradiente Descendente no aprendizado do MLP



43

© Prof. Emilio Del Moral – EPUSP


Foco na evolução dos w 's com as iterações ...



44

© Prof. Emilio Del Moral – EPUSP


Foco nos diferentes DeltaW de cada iteração ...



45

© Prof. Emilio Del Moral – EPUSP

Foco na evolução do Eqm com as iterações ...




46

© Prof. Emilio Del Moral – EPUSP

Plotando a evolução do Eqm com as iterações ...

Eqm(#)


Por construção, Eqm decresce a cada iteração, até estabilização em ponto de mínimo



47

© Prof. Emilio Del Moral – EPUSP

Como o que estamos aprendendo no domínio de equações analíticas se relaciona com o exercitado no ambiente MBP?



48

© Prof. Emilio Del Moral – EPUSP

Gráfico fornecido pelo ambiente MBP da evolução do Eqm com o número de repetidos usos da “bússola do gradiente descendente”: isto conecta o MBP com o gráfico apresentado no slide anterior





Gráfico fornecido pelo ambiente MBP da evolução do Eqm com o número de repetidos usos da “bússola do gradiente descendente”: isto conecta o MBP com o gráfico apresentado no slide anterior



O Ciclo completo da modelagem:

0) Formalização do problema, mapeamento quantitativo em um modelo neural inicial e ... 0b) coleta de pares empíricos (X,y)

1) Fase de TREINO da RNA (MLP): com conhecimento dos X e dos y, que são ambos usados na calibração do modelo

2) Fase de TESTE / Caracterização da qualidade da RNA para generalizar: temos novos pares X e y, com y guardado “na gaveta”, usado apenas para avaliação, não para re-calibração. É como um ensaio de uso final do modelo, com possibilidade de medir a sua qualidade com o y que foi guardado na gaveta.

[Fase de refinamentos da RNA, dados e modelo, em ciclos, desde 0]

3) Fase de USO FINAL da RNA, com y efetivamente não conhecido, e estimado com conhecimento dos X + uso do modelo calibrado.

.... Diferenças e semelhanças entre 1, 2 e 3

51

© Prof. Emilio Del Moral – EPUSP

Aprendizado do MLP por Error Back Propagation ...

$$\vec{\Delta W} = -\eta \cdot \vec{\nabla} E_{qm}$$


Gradiente de Eqm no espaço de pesos = $(\partial E_{qm}(W)/\partial w_1, \partial E_{qm}(W)/\partial w_2, \partial E_{qm}(W)/\partial w_3, \dots)$

Chegando às fórmulas das derivadas parciais, necessárias à Bússola do Gradiente


76

© Prof. Emilio Del Moral – EPUSP


Relembrando o que está por trás de um desenho como o que segue ...




© Prof. Emilio Del Moral – EPUSP





© Prof. Emilio Del Moral – EPUSP



© Prof. Emilio Del Moral – EPUSP



© Prof. Emilio Del Moral – EPUSP



Chamada oral sobre a lição de casa: estudar / reestudar os conceitos e a parte operacional de derivadas parciais, do vetor Gradiente ...

- Derivadas parciais (que são as componentes do gradiente):

$$\partial f(a,b,c)/\partial a \quad \partial f(a,b,c)/\partial b \quad \partial f(a,b,c)/\partial c$$

- Vetor Gradiente, útil ao método do máximo declive:

$$(\partial \text{Eqm}(W)/\partial w_1, \partial \text{Eqm}(W)/\partial w_2, \partial \text{Eqm}(W)/\partial w_3, \dots)$$

$$\vec{\Delta W} = -\eta \cdot \vec{\nabla} \text{Eqm}_-$$

86

© Prof. Emilio Del Moral – EPUSP

Invertamos o operador gradiente e a somatória

.. afinal, gradiente é uma derivada, e a derivada de um soma de várias funções é igual à soma das derivadas individuais de cada componente da soma:

$$\text{Grad}(\text{Eqm}) =$$

$$\text{Grad}(\sum_{\mu} \text{Eq}^{\mu}) / M$$

$$\sum_{\mu} \text{Grad}(\text{Eq}^{\mu}) / M$$

87

© Prof. Emilio Del Moral – EPUSP


Note que a inversão do gradiente com a somatória nada mais é que usar de forma repetida – e em separado para cada dimensão

do vetor **$\text{Grad}(\sum_{\mu} Eq^{\mu})$** – a seguinte propriedade simples e sua velha conhecida ...



$$d(f_1(x)+f_2(x)) / dx = df_1(x)/dx + df_2(x)/dx$$


88

© Prof. Emilio Del Moral – EPUSP



© Prof. Emilio Del Moral – EPUSP








Note que aqui temos uma cadeia com muitos estágios que levam da variável w_{1A} , à variável Eq^u , e para a qual podemos calcular a derivada da saída (Eq^u) com relação à entrada (w_{1A}) aplicando de forma repetida a seguinte propriedade simples e sua velha conhecida ...

$$d(f_1(f_2(x)) / dx = df_1(x)/df_2 \cdot df_2(x)/dx$$

..., ou seja, calculando isoladamente o valor da derivada para cada estágio da cadeia, e finalizando o cálculo de derivada de ponta a ponta nessa cadeia toda através do produto dos diversos valores de cada estágio.



Avisos que detalhei na aula de 02 de abril



A nossa P1 ocorrerá no horário de aula de PSI3471 e na semana de P1 (de E&S), como no calendário divulgado no início do semestre; mais precisamente, ocorrerá no dia 16 de abril, 2ª feira às 7:30 (com duração prevista de 90 mins).

98

© Prof. Emilio Del Moral – EPUSP

Avisos que comentei na aula de 02 de abril

Sistemas Eletrônicos Int x +

← → ↻ | edisciplinas.usp.br/mod/page/view.php?id=229836

DISCIPLINAS USP Apoio às disciplinas da USP

Acesso Senha USP

Início > Ambientes > 2018 > EP > PSI > Sistemas Eletrônicos Inteligentes I > Prova P1 > Regras de consulta a folha A1 própria apenas; data...

Regras de consulta a folha A1 própria apenas; data e local.

- 1) Como conversado em sala de aula, a consulta para a P1 está restrita a uma folha tamanho A4 própria preparada por você com suas anotações de estudo que considere mais relevantes, identificadas claramente com seu nome completo seu NUSP e assinatura, e que será entregue junto com a prova; escaneie / fotografe essa folha de estudos antes do dia da prova para seus arquivos.
- 2) No dia da prova não será permitido nem necessário o uso de computadores, celulares ou quaisquer eletrônicos, apenas será necessária a consulta a sua folha A4 de estudos previamente preparada, identificada e entregue com a prova.
- 3) A prova ocorrerá dentro do horário de aulas na semana de provas do 4o ano de Eletrônica e Sistemas. Se tiver dúvidas sobre essas datas, consulte a tabela de aulas e provas PSI3471 disponível no STOA desde o início do semestre e projetada sala na primeira semana de aulas.
- 4) O local da prova será a sala de aula ou sala maior a ser definida mais proximamente à prova.

No STOA também está definido desde o início do semestre quem pode fazer PSubs por perda da P1 e os documentos que devem ser apresentados na secretaria para análise pelos professores da solicitação do aluno.

Última atualização: terça, 20 Mar 2018, 08:46

99

© Prof. Emilio Del Moral – EPUSP

Lembretes

- Na maioria dos slides anteriores, onde aparece X , leia-se X^μ , não incluído para não complicar demais os desenhos
- ... similarmente, onde aparece y_{alvo} , leia-se y_{alvo}^μ . Idem para os Eq, leia-se Eq^μ
- Nos itens de cadeia de derivadas (f_A') e (f_C'), atenção para os valores dos argumentos, que devem ser os mesmos de f_A e f_C na cadeia original que leva w_{IA} a Eq.
- ... lembrando ... na cadeia original tínhamos ...
 - para f_C : $f_C(w_{AC} \cdot f_A(w_{IA} \cdot x_1 + w_{2A} \cdot x_2 + w_{0A}) + w_{BC} \cdot f_B(w_{1B} \cdot x_1 + w_{2B} \cdot x_2 + w_{0B}) + w_{0C})$
 - para f_A : $f_A(w_{IA} \cdot x_1 + w_{2A} \cdot x_2 + w_{0A})$
- Similarmente, para o bloco “quadrado”, cuja derivada é a função “2 vezes erro”, o argumento é $[y_{\text{rede}}(X, W) - y_{\text{alvo}}(X)]$

101

© Prof. Emilio Del Moral – EPUSP

Lembretes

- O mesmo que foi feito para w_{IA} deve ser feito agora para os demais 10 pesos: w_{2A} , w_{3A} , w_{0A} , w_{1B} , w_{2B} , w_{3B} , w_{0B} , w_{AC} , w_{BC} , e w_{0C} !
- Assim compomos um gradiente de 11 dimensões, com as derivadas de Eq^μ com relação aos 11 diferentes pesos w : $\text{Grad}_w(\text{Eq}^\mu)$
- Essas 11 fórmulas devem ser aplicadas repetidamente aos M exemplares numéricos de X^μ e y_{alvo}^μ , calculando M gradientes!
- Com eles, se obtém o gradiente médio dos M pares empíricos: $\text{Grad}_w(\text{Eqm}) = [\sum_\mu \text{Grad}_w(\text{Eq}^\mu)] / M$
- Esse gradiente médio é a Bussola do Gradiente!

102

© Prof. Emilio Del Moral – EPUSP

Método do Gradiente Aplicado aos nossos MLPs: a partir de um $W\#0$, temos aproximações sucessivas ao Eqm mínimo, por repetidos pequenos passos ΔW , sempre contrários ao gradiente ...

- “Chute” um W inicial para o “Wcorrente”, ou “ W melhor até agora”
- Em loop até obter Eqm zero, ou baixo o suficiente, ou estável:
 - Determine o vetor gradiente do Eqm, nesse espaço de W s
 - Em loop varrendo todos os M exemplos $(X^\mu; y^\mu)$,
 - Calcule o gradiente de Eq^μ associado a um exemplo μ , e vá varrendo μ e somando os gradientes de cada Eq^μ , para compor o vetor gradiente de Eqm, assim que sair deste loop em μ ;
 - Cada cálculo como esse, envolve primeiro calcular os argumentos de cada tangente hiperbólica e depois usar esses argumentos na regra da cadeia das derivadas necessárias
 - Dê um passo Delta ΔW nesse espaço, com direção e magnitude dados por $-\eta \cdot \text{vetor gradiente médio}$ para os M Exemplos $(X^\mu; y^\mu)$ de treino

103


© Prof. Emilio Del Moral – EPUSP

O que devemos mirar quando exploramos o espaço de pesos W buscando que a RNA seja um bom modelo?

Devemos mirar Maximização da aderência = Mínimo Eqm possível

As Setas Verdes Indicam Situações que Devem ser Procuradas

Será que temos apenas um mínimo??



104

© Prof. Emilio Del Moral – EPUSP

O Ciclo completo da modelagem:

0) Formalização do problema, mapeamento quantitativo em um modelo neural inicial e ... 0b) coleta de pares empíricos (X,y)

1) Fase de TREINO da RNA (MLP): com conhecimento dos X e dos y, que são ambos usados na calibração do modelo

2) Fase de TESTE / Caracterização da qualidade da RNA para generalizar: temos novos pares X e y, com y guardado "na gaveta", usado apenas para avaliação, não para re-calibração. É como um ensaio de uso final do modelo, com possibilidade de medir a sua qualidade com o y que foi guardado na gaveta.

[Fase de refinamentos da RNA, dados e modelo, em ciclos, desde 0]


3) Fase de USO FINAL da RNA, com y efetivamente não conhecido, e estimado com conhecimento dos X + uso do modelo calibrado.

.... Diferenças e semelhanças entre 1, 2 e 3

107

© Prof. Emilio Del Moral – EPUSP

Modelagem de um sistema por função de mapeamento $X \rightarrow y$
(a RNA como regressor contínuo não linear multivariável)




Assumimos que a variável y do sistema a modelar é uma função (normalmente desconhecida e possivelmente não linear) de diversas outras variáveis desse mesmo sistema

A RNA, para ser um bom modelo do sistema, deve reproduzir essa relação entre X e y , tão bem quanto possível

108

© Prof. Emilio Del Moral – EPUSP


Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



109

© Prof. Emilio Del Moral – EPUSP

A função $y(X)$ “a descobrir”, num caso geral de função contínua $y(X)$




110

© Prof. Emilio Del Moral – EPUSP


RNAs como reconhecedor / detetor de padrões

...



© Prof. Emilio Del Moral – EPUSP


Um hipotético universo de variáveis inter-dependentes, passível de modelagem/ens



112

© Prof. Emilio Del Moral – EPUSP

Caso de classificação binária / reconhecimento de padrões, será do tipo ...



113

© Prof. Emilio Del Moral – EPUSP